

Współczesna Gospodarka



Contemporary Economy
Electronic Scientific Journal
[Współczesna Gospodarka \(ug.edu.pl\)](http://Współczesna Gospodarka (ug.edu.pl))

Vol. 16 Issue 1 (2023) 27-43
ISSN2082-677X
DOI [10.26881/wg.2023.1.03](https://doi.org/10.26881/wg.2023.1.03)

INTERNET RZECZY I MODELE UCZENIA GŁĘBOKIEGO W ZRÓWNOWAŻONYM ROZWOJU INTELIGENTNYCH MIAST

Honorata Balicka

Streszczenie

Celem artykułu jest scharakteryzowanie kierunków zrównoważonego rozwoju inteligentnych miast w oparciu o wykorzystanie Internetu Rzeczy oraz modeli uczenia głębokiego. Zdaniem autorki taka strategia stwarza ogromną szansę na uniknięcie kryzysu w dużych miastach, wynikającego z negatywnych skutków pandemii, zagęszczania miast, zmian klimatycznych oraz zanieczyszczenia środowiska. W literaturze przedmiotu istnieje w tym zakresie luka, ponieważ brakuje jasnych koncepcji, jak wykorzystać wybrane technologie do zrównoważonego rozwoju inteligentnych miast. Z powyższych względów w artykule rozważa się strategię zastosowania Internetu Rzeczy oraz uczenia głębokiego, opartego na sieciach neuronowych do zwiększenia efektywności funkcjonowania miasta oraz poprawy jakości życia mieszkańców, dbając jednocześnie o środowisko naturalne. Scharakteryzowano zintegrowany system zarządzania miastem z zastosowaniem inteligentnych i ekologicznych technologii. Rolę i znaczenie Internetu Rzeczy opisano w kontekście zarządzania krytycznymi zasobami miasta. Natomiast zagadnienia związane z modelami uczenia głębokiego zaprezentowano pod kątem możliwości doskonalenia predykcji i przewidywania wyników. Przedstawiono rozważania dotyczące szczególnego przypadku architektury głębokiego uczenia opartej na sztucznych sieciach neuronowych (ANN). Rekurencyjne ANN klasy LSTM zweryfikowano pod kątem inwestycji finansowych na giełdzie. Na zakończenie przedstawiono konkluzje i planowane przyszłe prace. Wnioski wyciągnięte na podstawie przeprowadzonych badań jednoznacznie potwierdzają postawioną w pracy tezę, że Internet Rzeczy oraz modele uczenia głębokiego odgrywają kluczową rolę w zrównoważonym rozwoju inteligentnych miast.

Słowa kluczowe: Smart City, Ekologiczna Gospodarka, Internet Rzeczy, Uczenie Głębokie

Klasyfikacja JEL: G17, M15, O33.

Wstęp

Internet Rzeczy (IoT) oraz modele uczenia głębokiego dynamicznie rozwijają się w różnych obszarach współczesnej gospodarki, w tym również przyczyniają się do zrównoważonego rozwoju inteligentnych miast. Sztuczna inteligencja (SI) to nie tylko kontynuacja status quo na wyższym poziomie technologicznym, ale zmiana reguł gry praktycznie we wszystkich sferach aktywności gospodarczej. Możliwości jej zastosowania w przedsiębiorstwach poszczególnych branż zyskały duże zainteresowanie w światowych badaniach. Realizują je głównie znaczące ośrodki naukowe oraz firmy badawczo-konsultingowe. Według badania Gartnera większość kadry kierowniczej wyższego szczebla umiejscawia sztuczną inteligencję na pierwszym miejscu priorytetowych kierunków rozwoju w cyfrowej gospodarce opartej na wiedzy. Większość strategów korporacyjnych również podkreśla, że SI redefiniuje ich działalność w zupełnie nowy sposób, kreując nowe możliwości generowania zysków, niedostępne w gospodarce analogowej.

Nowoczesne technologie można rozpatrywać w dwóch kategoriach. Pierwsza kategoria dotyczy zdolności do utrzymania przy życiu oferowanych produktów i usług oraz przetrwania na istniejących rynkach. Natomiast druga kategoria zachęca podmioty gospodarcze do angażowania się w działalność nowatorską. Technologie IoT oraz SI są tymi, które intensyfikują czwartą rewolucję technologiczną, ponieważ stwarzają ogromną przestrzeń różnorodnych zdolności przetwarzania danych. Z tego względu znajdują one zastosowanie najczęściej w działaniach nowatorskich. Inteligentne miasta, które wykorzystują te technologie, są w stanie przetwarzać duże ilości danych i podejmować szybkie, skuteczne i zrównoważone decyzje, które przyczyniają się do poprawy warunków życia mieszkańców i ochrony środowiska naturalnego. Przewiduje się, że nowe, wydajne modele uczenia głębokiego oraz IoT będą podstawą harmonijnego rozwoju inteligentnych miast.

Duże miasta muszą radzić sobie z pewnymi otwartymi, ważnymi kwestiami, jak rosnąca populacja, wzrost natężenia ruchu oraz powstawanie zatorów drogowych, zanieczyszczenie powietrza, nieefektywne planowanie przestrzeni publicznej oraz brak kluczowych zasobów, takich jak woda czy energia. Kryzys gospodarczy związany z powszechną pandemią może wywołać poważne kryzysy w przeludnionych miastach. Z drugiej strony głębokie uczenie i IoT mogą wspierać miejskie systemy zarządzania z uwzględnieniem zielonej gospodarki. Dlatego zdecydowanie należy postawić na efektywne zarządzanie zasobami z wykorzystaniem głębokiego uczenia oraz IoT.

Celem artykułu jest scharakteryzowanie kierunków zrównoważonego rozwoju inteligentnych miast z zastosowaniem głębokich sieci neuronowych oraz IoT. Zdaniem autorki taka strategia stwarza szansę na uniknięcie kryzysu w dużych miastach, wywołanego rosnącymi skutkami pandemii, zagęszczeniem miast, zmianami klimatycznymi oraz zanieczyszczeniem środowiska. Warto podkreślić, że istnieje luka w literaturze przedmiotu w tym zakresie. Nie ma jasnych pomysłów, jak wykorzystać sztuczną inteligencję oraz Internet Rzeczy do zrównoważonego rozwoju smart city w ekologicznej i innowacyjnej gospodarce cyfrowej.

W ramach podstawowych metod badawczych zastosowano krytyczną analizę literatury przedmiotu. Ponadto wykorzystano modelowanie do symulacji możliwości wykorzystania głębokiego uczenia. Średni błąd szacowany jest na mniej niż 3% w przypadku korzystania z sieci neuronowych klasy LSTM. Należy przyjąć, że również pozostałe paradygmaty deep learningu będą skutecznym narzędziem w smart city.

Zasadnym jest zadanie następujących pytań. Jak skutecznie wspierać harmonijny rozwój smart city? Jak wykorzystać modele uczenia głębokiego oraz Internet Rzeczy? Jaki wpływ ma głębokie uczenie się i Internet Rzeczy na poprawę efektywności funkcjonowania miasta, jakość życia mieszkańców oraz środowisko naturalne? Odpowiedzi na te pytania postaram się przedstawić w niniejszym artykule.

Pozostała część artykułu jest zorganizowana w następujący sposób. W sekcji I scharakteryzowano zintegrowany system zarządzania w inteligentnym mieście, oparty na nowoczesnych i ekologicznych technologiach. W sekcji II opisano rolę i znaczenie jaką odgrywa Internet Rzeczy w zarządzaniu infrastrukturą oraz krytycznymi zasobami miasta. W sekcji III przedstawiono zastosowanie głębokiego uczenia w ramach doskonalenia precyzyjności przewidywania wyników. Podjęto rozważania dotyczące szczególnego przypadku architektury głębokiego uczenia, opartej na sztucznych sieciach neuronowych z pamięcią krótko- i długoterminową dla inwestycji giełdowych. Na koniec przedstawiono wnioski i rekomendowane kierunki rozwoju.

1. Zintegrowany system zarządzania w smart city

Zintegrowany system zarządzania w inteligentnym mieście to system, który łączy wiele różnych dziedzin i systemów w celu zapewnienia skutecznego i efektywnego zarządzania miastem. W skład takiego systemu mogą wchodzić m.in. systemy monitorowania ruchu miejskiego, systemy kontroli jakości powietrza, systemy zarządzania energią, systemy oświetlenia miejskiego, systemy inteligentnego zarządzania odpadami, systemy zarządzania parkowaniem, systemy zarządzania bezpieczeństwem publicznym oraz wiele innych.

Celem zintegrowanego systemu zarządzania w inteligentnym mieście jest zapewnienie skutecznego i efektywnego wykorzystania zasobów miejskich, a także poprawy jakości życia mieszkańców i ochrony środowiska. Dzięki takiemu systemowi możliwe jest np. zminimalizowanie korków drogowych poprzez koordynację sygnalizacji świetlnej, optymalizacja zużycia energii poprzez inteligentne zarządzanie oświetleniem i klimatyzacją, czy też zwiększenie skuteczności zbierania i utylizacji odpadów poprzez monitoring i sterowanie procesem ich gromadzenia i przetwarzania.

Wprowadzenie zintegrowanego systemu zarządzania w inteligentnym mieście wymaga inwestycji w rozwój infrastruktury technologicznej oraz wdrożenia odpowiednich systemów informatycznych i sensorów. Taki system może przyczynić się do znaczącej poprawy jakości życia mieszkańców oraz zwiększenia efektywności funkcjonowania miasta, co z kolei zwiększa atrakcyjność miasta nie tylko dla mieszkańców, ale także dla inwestorów.

Internet Rzeczy oraz sztuczna inteligencja mogą skutecznie wspierać zintegrowany system zarządzania z uwzględnieniem ekologicznych rozwiązań. Jednym z wyzwań stojących przed miastami jest nadmierne zagęszczenie. Prognozuje się, że do 2050 roku 68% populacji świata będzie żyć w miastach. W związku z tym duże miasta muszą radzić sobie z pewnymi ważnymi i otwartymi problemami. Zaliczają się do nich przede wszystkim wzrost natężenia ruchu oraz powstawanie zatorów drogowych. Pożądane jest również efektywne wykorzystanie przestrzeni publicznej oraz prywatnej. Niezbędne jest także odpowiednie zarządzanie zasobami. W wielu regionach świata już teraz istnieje ogromny problem z niedoborami kluczowych zasobów, takich jak woda czy energia.

Inteligentne miasto przyszłości wiąże się zwłaszcza z lepszą ochroną środowiska naturalnego. W dobrze zaprojektowanym mieście można znacząco zmniejszyć emisję gazów cieplarnianych *per capita*. Przewiduje się, że do krytycznych czynników warunkujących życie w miastach zaliczać się będzie globalne ocieplenie oraz emisja dwutlenku węgla. Obywatele oczekują więc wydajnego i zrównoważonego transportu w mieście nadającym się do zamieszkania. Oczekiwania mieszkańców dotyczą również zrównoważonego planowania urbanistycznego budynków ekologicznych (Amoruso, Dietrich, Schuetze, 2018). Za pomocą odpowiednich konstrukcji budowlanych można kontrolować temperaturę na ulicach.

Postępująca urbanizacja oraz wzrost liczby mieszkańców dużych miast powodują, że kluczowego znaczenia nabiera usprawnianie przemieszczania się w ramach metropolii oraz aglomeracji. Komplementarnym rozwiązaniem wobec pożądanych ekologicznych środków komunikacji miejskiej jest transport osobowy z wykorzystaniem lekkich urządzeń bez napędu

spalinowego, jak rowery, hulajnogi, skutery czy monocykle. Mikromobilność jest szczególnie istotna w sprawnym przemieszczaniu się na krótkie dystanse, w tym także w pokonywaniu tzw. pierwszego i ostatniego kilometra, czyli pomiędzy najbliższym przystankiem komunikacji miejskiej a miejscem docelowym.

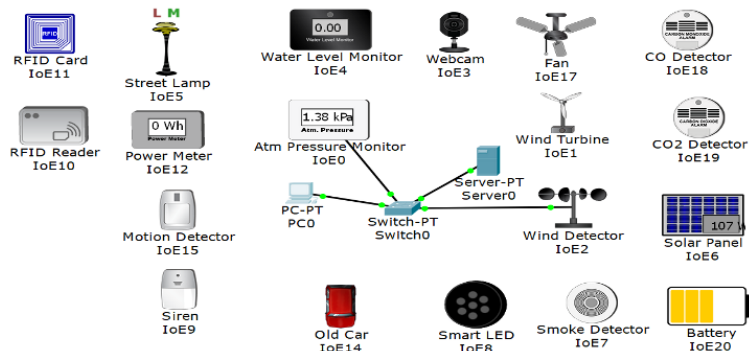
Istotną rolę w upowszechnianiu się efektywnego transportu osobowego odgrywają nowe modele biznesu oparte na współdzieleniu pojazdów w ramach oferty użytkowania społecznościowego, jak carsharing. Rozwój inteligentnego miasta w kierunku ekologicznej mikromobilności jest możliwy dzięki postępowi technologicznemu szczególnie w zakresie większej wydajności baterii, technologii GPS oraz funkcjonalności smartfonów.

Efekt synergii wydajnego wykorzystania zasobów ekologicznej komunikacji miejskiej oraz sprawnego przemieszczania się pozwalają uzyskać dedykowane aplikacje. Umożliwiają one integrację wszystkich dostępnych rozwiązań komunikacyjnych, poprzez lokalizację najbliższego środka transportu oraz precyzyjne planowanie intermodalnej trasy przejazdu. Ważną rolę w upowszechnianiu się ekologicznych sposobów mikromobilności odgrywa rozwój mikropłatności mobilnych udostępnianych w aplikacjach.

Podstawową zasadą finansową obowiązującą w inteligentnym mieście jest płacenie przez użytkownika tylko za wykorzystane zasoby, w tym też media, w oparciu o ich faktyczne, a nie prognozowane zużycie. Ze względu na fakt, że nie jest to możliwe na obecnym etapie rozwoju technologicznego miast, proponuje się IoT oraz uczenie głębokie (ang. deep learning). Ich zaimplementowanie w infrastrukturze smart city może skutecznie wspierać wiele ważnych zadań:

- bezobsługowe, zdalne odczyty urządzeń pomiarowych i automatyczne generowanie faktur rozliczeniowych, np. za zużyte media czy paliwo;
- zarządzanie zużyciem energii poprzez analizę ilości jej poboru w mieście i zidentyfikowanie sposobów na obniżenie jej zużycia i związanych z tym kosztów, co pozwala zmniejszyć wpływ miasta na środowisko naturalne oraz zapewnić mieszkańcom niższe rachunki za prąd;
- optymalizowanie i zapobieganie niedoborom wody, poprzez dokładną ocenę jej jakości, ilości, ale także poprzez dokładną analizę jej zużycia;
- monitorowanie stanu technicznego infrastruktury miejskiej, w tym zwłaszcza infrastruktury komunalnej, ale także budynków czy mostów w ramach systemu wczesnego ostrzegania przed potencjalnym zagrożeniem lub awarią;
- monitorowanie i zarządzanie środowiskiem naturalnym poprzez zbieranie danych o jakości powietrza, poziomie hałasu, ilości odpadów i innych parametrach środowiskowych w celu szybszego reagowania na kryzysy ekologiczne i poprawę jakości życia;
- zarządzanie transportem miejskim poprzez analizę danych związanych z ruchem ulicznym oraz popytem na transport publiczny w celu optymalizowania sieci transportowej, zapewniającej szybszy, bardziej efektywny i ekologiczny transport;
- inteligentną sygnalizację świetlną, zapewniającą płynność ruchu, poprzez przełączanie świateł dostosowanych do warunków drogowych;
- inteligentne arterie z komunikatami ostrzegawczymi i objazdami w zależności od warunków klimatycznych i nieoczekiwanych zdarzeń, takich jak wypadki lub zatory drogowe;
- szybkie docieranie do miejsc wypadku pojazdów uprzywilejowanych, poprzez inteligentne śledzenie pojazdów i zarządzanie flotą;
- inteligentne parkingi poprzez monitorowanie dostępności wolnych miejsc postojowych;
- inteligentne oświetlenie dróg, poprzez dostosowanie do warunków pogodowych oraz zapotrzebowania użytkowników;
- poprawę bezpieczeństwa w mieście poprzez analizę danych z monitoringu wizyjnego i detekcję anomalii zachodzących w przestrzeni publicznej w celu identyfikacji niebezpiecznych sytuacji i podjęcia adekwatnych działań prewencyjnych.

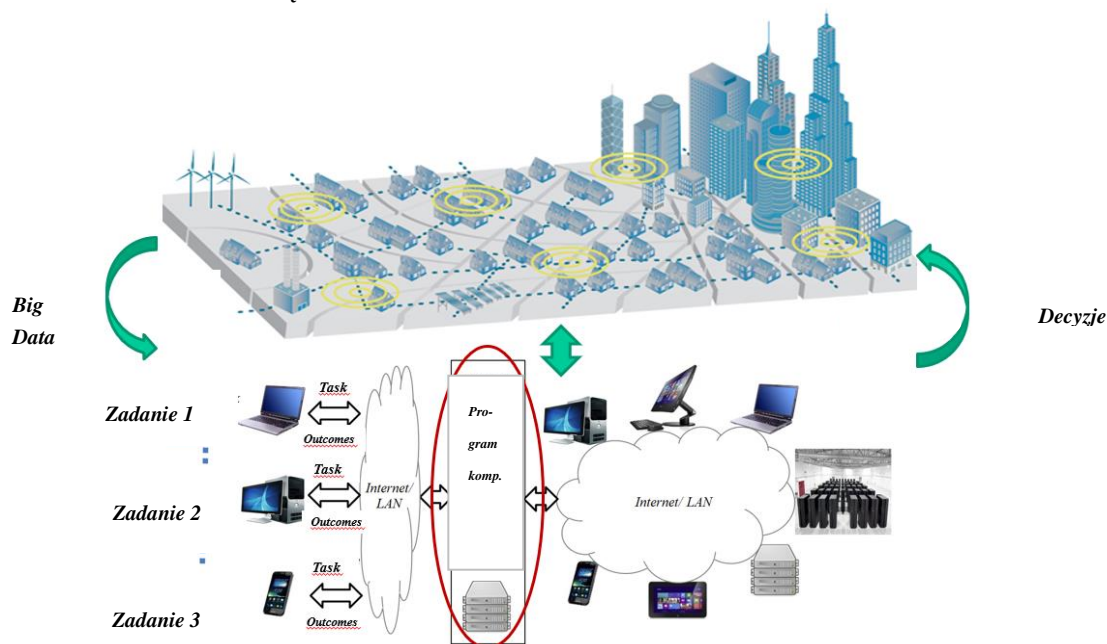
Deep learning oraz IoT należą do technologii dynamizujących cyfrową transformację gospodarki. W rozwoju inteligentnego miasta w kierunku zielonej gospodarki można rozważyć architekturę wielowarstwową, składającą się ze źródeł Internetu Rzeczy do gromadzenia danych, w tym m.in. z lamp ulicznych z czujnikami natężenia oświetlenia (ang. street lamp), monitorów poziomu wody (ang. water level monitor), kamer internetowych (ang. webcam), czujników ruchu (ang. motion detectors) czy czujnikami smogu (ang. smoke detector) (rys. 1).



Rysunek 1. Źródła Internetu Rzeczy w inteligentnym mieście

Źródło: Opracowanie własne.

Natomiast do generowania danych, niezbędnych dla zintegrowanego zarządzania miastem, można utworzyć nowoczesny rozproszony system komputerowy z różnego rodzaju czujnikami, wysyłającymi strumienie Big Data z domów, sieci samochodowych, parkingów, powietrza lub wody (żółte owale na rys. 2). Do analizy danych i uczenia maszynowego można wykorzystać również różne rodzaje komunikacji między czujnikami. Ze zgromadzonych i przetworzonych danych pozyskuje się informacje, które umożliwiają podjęcie optymalnych decyzji wspierających efektywne zarządzania strategicznymi zasobami, a także poprawę jakości życia mieszkańców oraz ochronę środowiska.



Rysunek 2. Zintegrowany system zarządzania w inteligentnym mieście

Źródło: Opracowanie własne na podstawie L. D. Gussin, *Smart Grid*, July 6, 2009. Pozyskano z: <https://insideclimateneeds.org/news/06072009/smart-grid-digging-foundations/>, 27.04.2023.


Złożone modele głębokiego uczenia inteligentnych miast wymagają dużej mocy obliczeniowej do szkolenia. Możliwości wykorzystania superkomputerów do realizacji zadań w inteligentnym mieście są ogromne, podobnie jak wyzwania stojące przed inteligentnymi miastami przyszłości. Na przykład Tokio jest największym miastem na świecie. Populacja jest obecnie szacowana na 37 milionów, w tym metropolia z 13 milionami. Japońscy projektanci najszybszego superkomputera Fugaku HPL wykorzystują go intensywnie do głębokiego uczenia. W teście obliczeniowym Linpack AI Fugaku osiąga moc obliczeniową 2 Eflo/s w oparciu o oprogramowanie do głębokiego uczenia TensorFlow lub PyTorch.

2. Rola i znaczenie Internetu Rzeczy w zintegrowanym systemie zarządzania miastem

Internet Rzeczy to technologia, która umożliwia połączenie wielu urządzeń, sensorów i sieci w jeden system, który może być zdalnie zarządzany i monitorowany. W kontekście miast, kluczową rolę IoT jest zbieranie danych z różnych źródeł i zarządzanie krytycznymi zasobami, takimi jak woda, energia, transport, odpady czy też bezpieczeństwo publiczne. Wdrożenie IoT pozwala miastu zebrać dużą ilość danych na temat infrastruktury i zasobów, co ma ogromne znaczenie z punktu widzenia możliwości zwiększenia efektywności zarządzania nimi. Wprowadzenie IoT wymaga zainstalowania sensorów i urządzeń, które umożliwiają zbieranie i przetwarzanie danych, które następnie są analizowane za pomocą specjalistycznych narzędzi i wykorzystywane do podejmowania decyzji. IoT może znacząco poprawić efektywność zarządzania miastem i przyczynić się do jego zrównoważonego rozwoju, a także oszczędności.

Wpływ przemysłu na środowisko staje się coraz bardziej widoczny, zwłaszcza w metropoliach. Już w latach 90. wielu przemysłowców zaczęło inwestować stosunkowo duże środki w przedsiębiorstwa, które minimalizowały degradację środowiska na rzecz prawdziwie zrównoważonego społeczeństwa miejskiego. Podkreślenia wymaga fakt, że około 70% wody stosowanej do nawadniania pozyskuje się z rzek, jezior i warstw wodonośnych. Dlatego ważna jest bieżąca kontrola wycieków chemikaliów, a także śledzenie w czasie rzeczywistym zmian ciśnienia w kanalizacji i sprawdzanie jakości wody w basenach. Ponad 80% ścieków wytwarzanych przez człowieka trafia do rzek lub mórz bez usuwania zanieczyszczeń. Czym to grozi? Szacuje się, że około 1000 dzieci umiera codziennie z powodu chorób biegunkowych związanych z dostępem do złego stanu wody lub urządzeń sanitarnych. Ponadto za 70% zgonów związanych z klęskami żywiołowymi odpowiadają powodzie i inne katastrofy związane z wodą. Nowoczesnym rozwiązaniem, które można wykorzystać aby przeciwdziałać wymienionym zagrożeniom jest Internet Rzeczy oraz głębokie uczenie. Ich zastosowanie umożliwia monitorowanie i inteligentną analizę danych w celu podjęcia stosownych działań prewencyjnych.

Na jakość życia mieszkańców istotnie wpływają działania w zakresie gospodarki wodnej (rys. 3). Niedobór wody dotyczy już około 40% światowej populacji i będzie się pogłębiał. Przewiduje się wzrost zapotrzebowania na wodę o 1/3 w 2050 r. Dlatego kluczowego znaczenia w zintegrowanym systemie zarządzania miastem nabiera optymalizowanie i zapobieganie niedoborom wody oraz ocena jej jakości. Istotną rolę w tym wypadku może odegrać dobrze zaprojektowany system IoT, który pozwala monitorować stan sieci wodociągowej, szybko wykrywać awarie i zapobiegać utracie wody, ale także poprzez analizę jej poboru, optymalizować zużycie.



Rysunek 3. Rozkład zużycia wody na świecie


Źródło: Libelium.org, <https://www.libelium.com/>, [dostęp: 18.03.2023].

Ponadto IoT dla gospodarki wodnej monitoruje również jakość wód powierzchniowych: rzek, jezior i wód przybrzeżnych, a także wody podziemne. Kontrola ekologiczna wykorzystuje wskaźniki biologiczne, hydromorfologiczne i fizykochemiczne. Jest to możliwe dzięki sieciom czujników, Internetowi Rzeczy, głębokiemu uczeniu i przetwarzaniu w chmurze, które wymagają inwestycji finansowych.

Kolejnym ważnym zasobem jest energia. Dlatego kluczowe znaczenie mają inwestycje finansowe w odnawialne źródła jej pozyskiwania, przesyłania oraz magazynowania. Nie mniej ważne jest powstawanie firm budujących panele fotowoltaiczne czy turbiny wiatrowe, a także promowanie usług, które zostaną opracowane w celu rozwoju ekologicznych technologii, takie jak ogniwa paliwowe w pojazdach hybrydowych, biopaliwa, produkcja alg, kukurydzy czy odpadów drzewnych do produkcji paliw. Analiza poziomu cen energii elektrycznej dla gospodarstw domowych na świecie wskazuje, że w państwach europejskich za energię płaci się najwięcej. Relatywnie tańszą od europejskiej energię pozyskują Stany Zjednoczone, a jeszcze lepsza sytuacja cenowa występuje w Chinach. Natomiast najtańsza energia jest dostępna w Afryce. Dlatego też inwestowanie w odnawialne źródła energii jest opłacalne przede wszystkim dla Europy (https://pl.globalpetrolprices.com/electricity_prices/, 2023).

W Polsce ceny energii są zazwyczaj nieco wyższe na północy niż na południu (<http://cena-pradu.pl/mapa.html>, 2023). Choć ceny energii w Polsce nie należą jeszcze do najwyższych, warto inwestować w odnawialne źródła energii oraz towarzyszące im nowe technologie. Rekomendowane są w szczególności rozwiązania technologiczne typu smart grids, które pozwolą zminimalizować straty związane z przesyłem pozyskanej energii od producentów do konsumentów, a także technologie umożliwiające magazynowanie energii.

Na poprawę efektywności zarządzania energią, a także na redukcję emisji CO₂ w znaczącym stopniu może wpłynąć wykorzystanie technologii IoT. Systemy monitorowania zarówno energii, jak i wody mogą zbierać dane dotyczące zużycia oraz jakości tych zasobów. Na podstawie zebranych danych można zoptymalizować dystrybucję oraz wykorzystanie strategicznych zasobów miasta. Rysunek 4 ilustruje przykładową architekturę IoT w inteligentnym mieście, w ramach której oprócz sieci czujników monitorujących strategiczne elementy wpływające na jakość życia w mieście, jak sensory smogu, temperatury i dźwięku (ang. smoke, temperature and sound sensors), znajdują się również niezbędne źródła energii odnawialnej, jak panele słoneczne (ang. solar panel) i turbiny wiatrowe (ang. wind turbine) wraz z urządzeniami do jej magazynowania, jak baterie (ang. battery).



Rysunek 4. IoT wspierający produkcję i magazynowanie energii z paneli słonecznych oraz turbin wiatrowych oraz monitorujący warunki meteorologiczne i zanieczyszczenie powietrza

Źródło: Opracowanie własne z wykorzystaniem oprogramowania Cisco Packet Tracer, <https://www.netacad.com/courses/packet-tracer>, [dostęp: 06.03.2023].

Bardzo ważnym obszarem wykorzystania zintegrowanego systemu zarządzania w dużym mieście, w oparciu o zastosowanie IoT oraz głębokiego uczenia jest bezpieczeństwo publiczne z możliwością predykcji czasu i miejsca popełnienia potencjalnego przestępstwa. Pomimo stosowania szeregu metod statystycznych, problem ten nie został rozwiązany od wieków. W walce z bezprawiem istotne wsparcie mogą stanowić algorytmy głębokiego uczenia, identyfikujące regiony o największym natężeniu przestępczości. Najważniejszą zaletą algorytmów deep learningu jest nie tylko kontrolowanie teraźniejszości na podstawie statystyki z przeszłości, ale głównie precyzyjne przewidywanie przyszłych zdarzeń. Z tego względu algorytmy głębokiego uczenia stosuje coraz więcej departamentów policji w USA w celu usprawnienia ścigania przestępców, w tym w szczególności przewidywania miejsca popełnienia czynu zabronionego. Tego rodzaju rozwiązania są stale aktualizowane, ulepszone i rozwijane, aby zapewnić jak największą wydajność (Balicki, Korłub, Paluszak, 2015).

Do przedstawienia średniej wartości danego zjawiska, do jakiego zalicza się m.in. liczbę przestępstw popełnianych w jednostce przestrzennej, opracowuje się kartogramy. Kartogram pozwala wyznaczyć niebezpieczne obszary, w tym także wskazać rodzaj i czas popełnienia potencjalnego przestępstwa. Mapy zagrożeń bezpieczeństwa, wsparte technologią IoT oraz uczeniem głębokim, są przygotowywane z precyzją przekraczającą możliwości zespołów ludzkich. Jednym z przykładów jest aplikacja HunchLab, która pozwala niemal bezbłędnie przygotować kartogramową mapę zagrożeń (Aguirre, Badran, Muggah, 2019). Wspomniana aplikacja służy zarówno do przewidywania, czasu i miejsca przestępstwa, jak i do regulowania pracy policji. Za pomocą HunchLab oblicza się współczynniki równoważności, rozkładając bezpieczeństwo na terytorium w oparciu o wiele kryteriów dotyczących kosztów oraz sprawiedliwości społecznej. Zastosowanie aplikacji do głębokiego uczenia HunchLab zaowocowało zmniejszeniem przestępczości w Filadelfii o 31%, a także wzrostem zaufania do policji (Benbouzid, 2019).

Innym przykładem jest aplikacja PredPol (Aguirre, Badran, Muggah, 2019) umożliwiająca określenie ekonomicznego aspektu działania policji. PredPol ocenia wartość działań patrolu za pomocą klasycznej formuły obliczania zwrotu z inwestycji:

$$\text{ROI} = (\text{zyski} - \text{koszty inwestycji}) / \text{koszty inwestycji} \quad (1)$$

Zastosowanie wskaźnika ROI pozwala ocenić pracę policji w kategoriach księgowych poprzez ustalenie ekwiwalentu między unikniętymi kosztami bądź osiągniętymi zyskami a podjętymi przez policję działaniami. Ocena zwrotu z inwestycji wymaga pięniężnego oszacowania kosztu przestępstwa, co umożliwi policji wyrażenie jej przewidywanego działania w wartościach pięniężnych.

Obie aplikacje, tj. HunchLab oraz PredPol, są wspierane przez IoT, aby zapewnić interoperacyjność systemu z wykorzystaniem technologii bezprzewodowej, w tym komunikacji LPWAN, istotnej dla projektu inteligentnego miasta. Natomiast kompatybilność z platformą władz miejskich zapewnia chmura, w której znajdują się centra danych. Warto również podkreślić, że PredPol jest zasilany energią słoneczną i wykorzystuje baterie o dużej wydajności, co przyczynia się do minimalizacji kosztów utrzymania systemu. Zapewnienie wysokiego poziomu bezpieczeństwa w mieście przynosi wiele wymiernych korzyści. Należy do nich zwiększenie komfortu życia jego mieszkańców, co przekłada się na lepsze wyniki w pracy, rozwój handlu, wzrost kwot płaconych podatków, a także zmniejszenie ilości niespłaconych kredytów. Tej klasy systemy wykorzystuje się nie tylko do analizy statystyk dotyczących przestępczości z przeszłości. Znajdują one zastosowanie również do gromadzenia i przetwarzania danych o pogodzie, lokalizacjach bankomatów czy do precyzyjnego planowania eventów.

Podobnie jak woda, energia elektryczna i bezpieczeństwo do harmonijnego funkcjonowania w dużym mieście potrzebne jest również czyste powietrze. IoT i głębokie uczenie mogą umożliwić szybkie gromadzenie danych i przewidywanie zmian zagrożeń związanych z zanieczyszczeniem powietrza w przyszłości. Mieszkańcy miasta powinni być poinformowani o strefach zanieczyszczenia na przykład poprzez dedykowane aplikacje, które wymagają dokładnych odczytów, w tym między innymi o stężeniu gazu. Przydatne do pomiaru dokładnej wartości stężenia gazu w jednostkach PPM są skalibrowane czujniki gazów o wysokiej dokładności (rys. 5). Czujniki cząstek stałych pozwalają mierzyć intensywność kilku cząstek, takich jak PM1, PM2,5 i PM10. Algorytmy głębokiego uczenia umożliwiają predykcję obszarów największego zanieczyszczenia powietrza, jak również poziomu stężenia poszczególnych zanieczyszczeń. Ich monitorowanie pozwala zapobiegać powstawaniu szkodliwych dla zdrowia zanieczyszczeń w centrach miast. Równie ważnym problemem jest wykrywanie szczególnie niebezpiecznych zjawisk rzadkich. Należą do nich między innymi chmura dwutlenku siarki z wulkanu oraz kwaśne deszcze z wysokim poziomem stężenia kwasu siarkowego. Dbalność o czyste powietrze przynosi wymierne korzyści wynikające z mniejszego nasilenia chorób oraz wydłużenia życia obywateli.

Stworzenie zintegrowanego systemu zarządzania w inteligentnym mieście, wspieranego przez IoT oraz algorytmy głębokiego uczenia, wymaga bez wątpienia dobrze ukierunkowanych inwestycji finansowych. Powinny one dotyczyć przede wszystkim nowych i ekologicznych technologii informatycznych, w tym komputerów, routerów, przełączników, smartfonów oraz różnego rodzaju czujników. Beneficjentami nowych technologii powinny być przede wszystkim uczelnie, w których kształcą się studenci oraz przeprowadza się badania naukowe. Adresatami wsparcia finansowego powinny być również przedsiębiorstwa typu start-up. Bardzo dobrym miejscem inwestowania kapitału są giełdy, na których notowane są spółki, oferujące innowacyjne i ekologiczne rozwiązania służące zrównoważonemu rozwojowi inteligentnych miast.

3. Predykcyjna funkcja uczenia głębokiego

Do przewidywania trendów w finansach można wykorzystać równoległe algorytmy głębokiego uczenia. Wymagają one jednak dużej mocy obliczeniowej komputerów (Mylonakis, Diacogiannis, 2010). Z tego względu prognozy powstające z ich udziałem mogą być wykonane z zastosowaniem chmur obliczeniowych (Balicki, Balicka, Dryja 2021). Interesującym przykładem połączenia głębokiego uczenia i obliczeń równoległych jest wyposażony w sztuczną inteli-

gencję superkomputer IBM Watson, który pomaga w podejmowaniu decyzji. Znalazł on już zastosowanie w diagnostyce medycznej, w której 90% przypadków rozpoznania raka płuc zachodzi z jego udziałem (Balicki, Korłub, Tyszka, 2016). Watsona z umiejętnościami rozpoznawania mowy i wiedzą medyczną wykorzystuje w diagnostyce medycznej firma Nuance Communications Inc. IBM bada również wykorzystanie Watsona jako asystenta prawnika. Do perspektywicznych obszarów zastosowań Watsona należą także prognozy finansowe (Shouwei, Mingliang, Jianmin, 2013).

Programowanie genetyczne jest bardzo dobrą alternatywą dla klasycznych aplikacji giełdowych, takich jak CRISMA, która bazuje na analizie technicznej i określa zwrot z inwestycji w ciągu dekady, przy założeniu 2% kosztów transakcyjnych. Do nauki i testowania programów bazujących na algorytmach genetycznych wykorzystuje się dane giełdowe za dany okres (Chen, Kuoand, Hoi, 2006). Na ich podstawie algorytmy genetyczne tworzą reguły podejmowania decyzji podczas dynamicznie zmieniających się warunków na giełdzie. Rezultaty programowania genetycznego porównywane są ze strategią „kup i trzymaj” (Schwaerzel, 2006), oraz z bardziej zaawansowanymi metodami autoregresyjnymi (Svangard, 2002). Klasyczne podejście „kup i trzymaj” może być jednak skuteczne tylko w sytuacji, gdy sektor, w którym działa spółka akcyjna jest obiecujący. Tylko w takich warunkach inwestor może sobie pozwolić na trzymanie akcji przez relatywnie długi czas i sprzedać je dopiero w sytuacji, gdy może osiągnąć zysk (Potvin, Soriano, Vall, 2004). Programowanie genetyczne pozwala natomiast stworzyć reguły kupna i sprzedaży, które mogą zostać uruchomione po spełnieniu określonych warunków. Ustalanie reguł odbywa się przy uwzględnieniu odpowiednich preferencji inwestora, które zazwyczaj dotyczą kompromisu pomiędzy wysokością oczekiwanego zysku a akceptowalnym poziomem ryzyka.

Głębokie uczenie oparte na modelach behawioralnych doskonale wpisuje się w wymagania analizy rynku kapitałowego, czyniąc to podejście szczególnie skutecznym (Henley, Hand 1996). Transakcje z wykorzystaniem behawioralnych modeli uczenia głębokiego przeprowadza się najczęściej z udziałem agentów programistycznych. Tego typu modele znajdują zastosowanie w szczególności w dwu obszarach. Pierwszy, dotyczy symulacji zjawisk zachodzących na rynkach kapitałowych. Natomiast drugi, odnosi się do wspomaganie decyzji podejmowanych na giełdzie papierów wartościowych. Wykorzystanie wirtualnego agenta wyróżnia się na tle innych podejść tym, że uwzględniania aspekty psychologiczne w procesie podejmowania decyzji finansowych, zwłaszcza w zakresie nastawienie na zysk oraz skłonności do podejmowania ryzyka, które z kolei zależą od osobowości inwestora.


Rynki finansowe są bardzo dobrym obszarem zastosowania uczenia głębokiego, ponieważ występuje na nich duża liczba czynników wpływających na aktualne trendy. Pełna analiza czynników przekracza możliwości decyzyjne człowieka. Rynek kapitałowy modeluje się jako zbiór autonomicznych podmiotów, z których każdy ma ten sam cel, którym zwykle jest zysk osiągany w warunkach niepewności. Należy podkreślić, że istotną cechą wyróżniającą agentów programistycznych jest zdolność adaptacji do szybko zachodzących zmian w środowisku dynamicznym. Symulacja i analiza zachodzących zjawisk na rynku kapitałowym jest możliwa dzięki modelowaniu interakcji między rywalizującymi agentami wirtualnymi. Brana jest również pod uwagę możliwość współpracy i negocjacji agentów. Symulacja interakcji pomiędzy agentami pozwala zweryfikować reakcję rynku na określone zdarzenia. Pozwala zwłaszcza antycypować reakcję rynku na zmiany stóp procentowych lub określać wpływ innych zdarzeń na sytuację rynkową, co pozwala uniknąć problemów ze stabilnością systemu finansowego (Bosse, Sid-diqui, Treur, 2010).

Symulowanie sytuacji rynkowej znacząco wspiera proces przewidywania trendów, co pozwala na formułowanie rekomendacji dotyczących transakcji. Są one niezwykle ważne dla skutecznego podejmowania decyzji w krótkim czasie. Dlatego na rynek kapitałowy wprowadza się agentów komputerowych, którzy automatycznie wykonują transakcje w imieniu inwestorów na

podstawie określonych rekomendacji. Przewaga agenta programistycznego nad człowiekiem polega na nieograniczonych możliwościach czasu pracy oraz szybkości reakcji, które należą do kluczowych czynników powodzenia transakcji na rynku kapitałowym, gdzie transakcje kupna i sprzedaży akcji zachodzą w ułamku sekundy (Balicki, 2013).

Wśród najskuteczniejszych metod inwestowania na giełdzie wymienia się sztuczne sieci neuronowe (ang. *Artificial Neural Networks* - SSN) z pamięcią długoterminową (ang. *Long Short Term Memory* - LSTM) (Gately, 1999). Do uczenia sieci neuronowych służą historyczne dane szeregów czasowych, dostępnych w ramach analizy technicznej. Wielowarstwowe sztuczne sieci neuronowe umożliwiają precyzyjną predykcję wartości badanych cech (Nazari, Alidadi, 2013). Mogą one dotyczyć zarówno wartości liczbowych, jak i symbolicznych. Przy przewidywaniu wartości liczbowych mówimy o regresji, a w przypadku wartości symbolicznych o klasyfikacji. Na rynku kapitałowym mamy do czynienia ze specyficznym problemem przewidywania szeregów czasowych (Baesens, 2003). Dążąc do uzyskania jak najdokładniejszych wyników prognozy, uczący się algorytm umożliwia dostosowanie odpowiednich wag synaptycznych (Davis, Karim, 2008). Należy przy tym podkreślić, że przeanalizowanie tak wielu zestawów treningowych dla uzyskania jak najlepszego wyniku prognozy wymaga dużej mocy obliczeniowej, dostępnej tylko na superkomputerach. Ich posiadanie stanowi istotną barierę zmuszającą często do znacznego zmniejszenia intensywności pobieranych danych z giełdy, co może skutkować mniejszą precyzją antycypowanych wyników.

Specyfika działania sieci LSTM polega na zapamiętywaniu stanu komórki pamięci, która przechodzi przez informację komórki, a następnie jest akceptowana lub usuwana ze stanu komórki przez zawory. Blok LSTM składa się z szeregu połączonych elementów, w tym z trzech zaworów lub bramek (wejście, zapomnienie i wyjście), a także wejścia bloku, komórki pamięci i funkcji aktywacji wyjścia (Kumar, Haider, 2021). Proces działania LSTM, w którym odbywają się operacje punktowe na okręgach, zaprezentowano na rysunku 5. Informacje, których algorytm nauczył się we wcześniejszych krokach zapisywane są w prostokątach. Linie łączące się oznaczają konkatencję, natomiast linie rozbieżne świadczą o tym, że powielona treść trafia do dwu różnych lokalizacji. Tego, jak chronić blok liniowy przed fałszywymi sygnałami, uczą się funkcje sigmoidalne (zawory). Przed nieistotnymi zdarzeniami wejściowymi blok LSTM chroniony jest przez zawór pierwszy. Jest to możliwe dzięki funkcji sigmoidalnej, do której przekazywany jest poprzedni stan i bieżące wejście. W dalszej kolejności funkcja tanh przekształca te same wartości wejściowe pomiędzy -1 a 1. Później oba wyjścia są mnożone przez siebie, a funkcja sigmoidalna rozstrzyga, które wartości z funkcji tanh zostaną zachowane.



Rysunek 5. LSTM ANN do obsługi inwestycji giełdowych

Źródło: Atsalakis G., Valavanis K., (2013), *Surveying stock market forecasting techniques - Part I: Conventional methods in Computation Optimization in Economics and Finance Research Compendium*, New York, Nova Science Publishers, p. 35.

Z kolei druga funkcja sigmoidalna tworzy blokadę umożliwiającą zapomnienie poprzedniej zawartości pamięci. Tym samym poprzez funkcję sigmoidalną przekazywany są informacje zarówno ze stanu poprzedniego, jak i bieżącego wejścia. Wyjście funkcji stanowią wartości od 0 do 1, które decydują o istotności danej informacji. Natomiast trzecia funkcja sigmoidalna reprezentuje zawartość pamięci na wyjściu. Zmodyfikowany stan informacji jest następnie przekierowywany do funkcji tanh. Oba wyjścia są mnożone, w celu identyfikacji i zachowania tylko tych informacji, które mogą być przekazane do kolejnego kroku czasowego (Aslam, 2021).

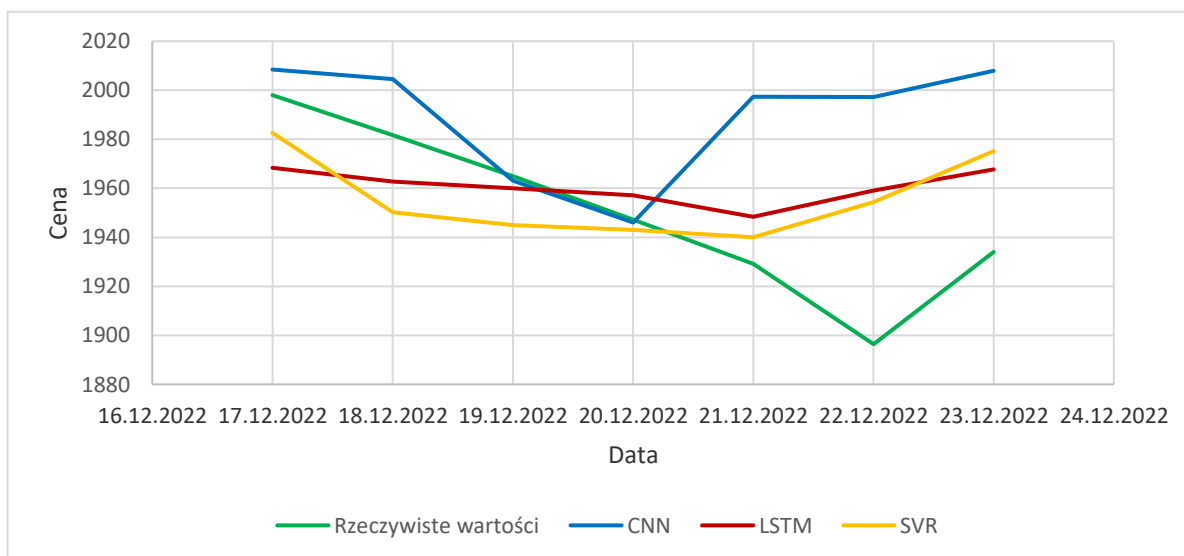
Prognozowanie jest również utrudnione przez niewielką ilość informacji w kolumnach. Notowania na Giełdzie Papierów Wartościowych w Warszawie podawane są w pięciu kolumnach i przedstawiają odpowiednio kursy: otwarcia, najwyższy w danym dniu, najniższy w danym dniu, zamknięcia oraz wolumen obrotu. W tej sytuacji sieć neuronowa musi bazować tylko na pięciu podstawowych cechach, które dodatkowo zależą w dużym stopniu od czynników losowych. Problem zalicza się do trudnych ze względu na to, że pomimo potencjalnie niskiego stopnia złożoności, wynikającego z małej liczby cech, człowiek nie może go rozwiązać z tak dużą wydajnością, jaką umożliwiają modele uczenia głębokiego, oparte na sztucznych sieciach neuronowych. Przed użyciem informacji do uczenia sieci neuronowych, wskazane jest wstępne przetworzenie danych, aby wydobyć z nich jak największą liczbę informacji. W pierwszej kolejności problem sprowadza się do analizy szeregów czasowych. W jednym przykładzie uczącym zachodzą procentowe zmiany wartości bazowych dla wybranej liczby następujących po sobie sesji giełdowych. Kolejne przykłady dydaktyczne powinny być rozszerzone o wartości wskaźników giełdowych, które można podzielić na dwie grupy, a mianowicie na wskaźniki zależne i niezależne od opóźnienia.

Symulowaną zależność osiągniętego zysku od predyktorów neuronowych CNN i LSTM zilustrowano na rysunku 6. Analizowana jest również regresja wektora nośnego SVR. W celu przeprowadzenia symulacji wykorzystano akcje WIG20. LSTM został przeszkolony 16 grudnia 2022 r. na podstawie historii jednomiesięcznych szeregów czasowych danych od 17 listopada do 16 grudnia. Następnie prognozy zostały wykonane dla okresu w przyszłości od 17 grudnia do 23 grudnia. Równoległe zostały przeprowadzone dwie inne prognozy, które zrealizowano za pomocą regresji wektora nośnego (ang. Support Vector Regression - SVR) (Awad, Khanna, 2015) oraz konwolucyjnych sieci neuronowych (ang. Convolutional Neural Networks - CNN) (Balicki, 2009). Rzeczywiste wartości WIG20, które zostały zebrane w ciągu siedmiu dni, ilustruje linia w kolorze zielonym. Daje się zauważyć, że prognozy LSTM (bordowa linia) są bardzo zbliżone do rzeczywistych wartości WIG20.

Ze względu na fakt, że zastosowanie głębokich sieci neuronowych sprawdza się w optymalizacji kombinatorycznych problemów NP-trudnych (Staniec, 2003), wykorzystuje się je również w optymalizacji portfela akcji. Bardzo dobrym obszarem zastosowania sztucznej inteligencji w oparciu o głębokie sieci neuronowe jest analiza zdolności kredytowej klientów banków (Yobas, Crook, Ross, 2000), ale także analiza ryzyka związanego z niespłacalnością kredytów hipotecznych (Zan et al., 2004). Ponadto w oparciu o sztuczne sieci neuronowe budowane są strategie ustalania stawek, prognozowane są również wartości indeksów (German Credit dataset, 2021). Rozpoznawanie kierunków trendów na giełdzie, określanie poziomów ryzyka związanego z inwestowaniem w określone rodzaje instrumentów finansowych, jak również identyfikowanie prawidłowości rządzących cenami instrumentów finansowych oraz prognozowanie upadłości można efektywnie realizować za pomocą głębokich sieci neuronowych (Brown 2011).

Ze względu na zbyt silny wpływ czynnika losowego, który bierze się pod uwagę w wielu modelach, nie da się przewidzieć efektywnego rozwiązania finansowego za pomocą modelu matematycznego. W przeciwieństwie do tych modeli, sieci neuronowe nie zawierają żadnych założeń a priori dotyczących analizowanych procesów. Tym samym są one predystynowane do identyfikacji lokalnych zakłóceń lub zależności zachodzących na rynku w krótkim czasie.

Obecnie transakcje na rynku zostały w dużej mierze zautomatyzowane i wykorzystuje się do ich przeprowadzania wirtualnych brokerów, co stanowi alternatywną metodę inwestowania na giełdzie. Skomputeryzowane systemy transakcyjne są wykorzystywane zwłaszcza w transakcjach o wysokiej częstotliwości (ang. high-frequency transactions - HFT), na które składają się tysiące transakcji podczas sesji. Zwykle w takich systemach stosowane są algorytmy oparte na sztucznych sieciach neuronowych. Zautomatyzowanie operacji oraz wykorzystanie sztucznej inteligencji spowodowało, że obecnie na największych giełdach inwestor może trzymać akcje zaledwie przez milisekundy, a nawet mikrosekundy. Podczas gdy jeszcze do 1998 roku można było trzymać akcje przez kilka sekund, po których dopiero je sprzedawano.



Rysunek 6. Porównanie wyników przewidywanego zysku na siedmiodniowy okres od dnia zawarcia transakcji.

Źródło: Own study

Wybrane metody uczenia głębokiego, które zostały zaprezentowane w niniejszym artykule, na przykładzie inwestycji giełdowych, nie wyczerpują dużego potencjału efektywnego wykorzystania innych metod sztucznej inteligencji w systemach finansowych. Interesującym rozwiązaniem jest między innymi zastosowanie algorytmu harmonicznego do skrócenia czasu reakcji systemu bankowości internetowej, umożliwiającego zwiększenie wydajności i odporności systemu na ataki hakerskie, a także redukcję kosztów. Ważne znaczenie mają także wieloprocesorowe karty graficzne. Obszarem ich efektywnego zastosowania jest w szczególności analiza modeli ekonometrycznych. Aldrich i in. pokazują, że podczas analizy cykli koniunkturalnych procesory graficzne wykonują obliczenia 200 razy szybsze niż tradycyjne procesory (Aldrich, 2011). Warto podkreślić, że nowoczesne systemy informatyczne wymagają również odpowiednio dostosowanych planów kont, aby zwiększyć efektywność i bezpieczeństwo ich wykorzystania w rozproszonym środowisku obliczeniowym (Gierusz, Koleśnik, 2021). Optymalny plan kont powinien być rozproszony w obszarach, w których dokonuje się najistotniejszych operacji w celu minimalizacji prawdopodobieństwa ataku w cyberprzestrzeni. Istotnym obszarem zastosowania wyszkolonych modeli głębokiego uczenia jest także klasyfikacja wiarygodności pożyczkobiorców w celu zmniejszenia kwoty niespłaconych pożyczek. Tego typu modele są szczególnie przydatne do predykcji kryzysów w krajowym sektorze bankowym (Balicka, 2014).

Uważa się, że gospodarka USA odnosi sukcesy dzięki agresywnej absorpcji zaawansowanych technologii. Tamtejszy przemysł obronny, który rozwija technologie „podwójnego zastosowania”, został wezwany do udostępnienia głębokiego uczenia oraz IoT innowacyjnym przedsiębiorcom. Warto odnotować, że przy opracowywaniu produktów, producenci azjatyccy również wspierają się sztuczną inteligencją. Ogromny wpływ na rozwój modeli głębokiego uczenia wywarły problemy z modelowaniem klimatu. Symulacja ekstremalnych opadów przez francuską firmę ARIA Technologies pozwoliła dostarczyć firmom ubezpieczeniowym precyzyjnych prognoz wystąpienia ryzyka powodziowego. Symulowany jest również wpływ zmian klimatu na zagrożenia naturalne. Projektem, o którym warto wspomnieć jest IBM Blue Brain, próbujący symulować ludzki mózg. W wypadku wspomnianego projektu należy liczyć się z modelowaniem 100 miliardów neuronów i 1 biliona połączeń neuronowych. Do modelowania ludzkiego mózgu potrzebny będzie 1 eksabajt pamięci RAM, podczas gdy najszybszy superkomputer ma obecnie 1000 razy mniejszą pojemność pamięci. Blue Brain znajdzie zastosowanie w wielu obszarach biznesu i przemysłu, w tym również w zrównoważonym rozwoju inteligentnych miast. Można zatem skonstatować, że aplikacje medyczne IBM Watsona niekoniecznie będą priorytetowe (Balicki, 2015; Hanschel, Monnin, 2005).

Zakończenie

Wykorzystanie zielonych i nowoczesnych technologii informatycznych opartych na Internecie Rzeczy oraz modelach głębokiego uczenia, ze szczególnym uwzględnieniem sieci neuronowych, stwarza ogromną szansę na zrównoważony rozwój inteligentnych miast. W artykule przedstawiono w szczególności możliwości wykorzystania głębokich sieci neuronowych, zaimplementowanych na superkomputerach, za pomocą których można opracować nowoczesny i efektywny system zintegrowanego zarządzania dużym miastem.

W artykule omówiono zintegrowany system zarządzania, uwzględniający skuteczne i efektywne wykorzystanie zasobów miejskich, a także poprawę jakości życia mieszkańców przy jednoczesnym poszanowaniu środowiska naturalnego. Internet Rzeczy opisano w kontekście ekologicznego zarządzania krytycznymi zasobami miasta. Ponadto scharakteryzowano zagadnienia związane z głębokim uczeniem w zakresie predykcji wyników. Wreszcie zaproponowano wykorzystanie sztucznych sieci neuronowych z pamięcią długoterminową do inwestycji giełdowych.

W odpowiedzi na postawione we wstępie artykułu pytanie należy stwierdzić, że harmonijny rozwój ekologicznych i inteligentnych miast przyszłości może być skutecznie wspierany przez rozsądne inwestowanie w deep learning oraz Internet Rzeczy. Na potwierdzenie tak postawionej hipotezy, przytoczono wiele przykładów. Kluczowe znaczenie ma sfinansowanie budowy inteligentnej miejskiej infrastruktury komputerowej, która pozwoli uzyskać przejrzysty obraz złożonej sytuacji decyzyjnej. Istotne jest również osiągnięcie efektu synergii ze zrównoważonej interakcji kluczowych elementów zintegrowanego systemu zarządzania miastem.

Natomiast odpowiadając na pytanie, jak wykorzystać modele uczenia głębokiego oraz Internet Rzeczy można skonstatować, że złożone modele bazujące na sztucznych sieciach neuronowych inteligentnych miast wymagają dużej mocy obliczeniowej do szkolenia. Z drugiej jednak strony predykcja, klasyfikacja i wspomaganie decyzji przez wyszkolony model sztucznej inteligencji wymaga znacząco mniej zasobów. Reasumując, wpływ deep learningu i Internetu Rzeczy na kierunki zrównoważonego rozwoju inteligentnych miast jest znaczący.

Perspektywicznym kierunkiem badań jest rozwój innych modeli głębokiego uczenia, jak chociażby Convolutional Neural Networks do antycypowania kryzysów bankowych. Istotnym problemem jest również wykorzystanie głębokich sztucznych sieci neuronowych do analizy wiarygodności potencjalnych kredytobiorców.

Bibliografia

- Aguirre K., Badran E., Muggah R. (2019). Future crime: Assessing twenty first century crime prediction. Igarapé Institute. Strategic Note 33, July. Pozyskano z: https://igarape.org.br/wp-content/uploads/2019/07/2019-07-12-NE_33_Future_Crime.pdf, (27.03.2023).
- Aldrich E., Fernández-Villaverde M., Gallant J.R., Rubio-Ramírez A., Juan F. (2011). *Tapping the supercomputer under your desk: Solving dynamic equilibrium models with graphics processors*. "Journal of Economic Dynamics and Control", Vol. 35(3), p. 387.
- Amoruso F. M., Dietrich U., Schuetze T. (2018). *Development of a Building Information Modeling-Parametric Workflow Based Renovation Strategy for an Exemplary Apartment Building in Seoul*. Korea. "Sustainability", 10(12), 4494; <https://doi.org/10.3390/su10124494>, pp. 1-30.
- Aslam S., Rasool A., Jiang Q., Qu Q. (2021). *LSTM based Model for Real-time Stock Market Prediction on Unexpected Incidents*. RCAR, p. 1149.
- Awad M., Khanna R. (2015). *Support Vector Regression: Efficient learning machines*. Apress, Ber-keley, CA, p. 223.
- Baesens B., Setiono R., Mues C., Vanthien J. (2003). *Using neural network rule extraction and decision tables for credit-risk evaluation*. "Management Science", Vol. 49, No. 3, March, p. 317.
- Balicka H., Balicki J., Korłub W., Paluszak J., Zadroga M. (2014). *Superkomputery do wspomagania procesów gospodarczych ze szczególnym uwzględnieniem sektora bankowego*. „Współczesna Gospodarka”, Issue 5, Vol. 4, ss. 1-16, <https://doi.org/10.23830/16/II/2019/5788>, pp. 57-88.
- Balicka H. (2019). *Cloud computing and selected models of deep learning in banking*. "Przestrzeń, Ekonomia, Społeczeństwo", Issue No. 16 II.
- Balicka H. (2023). *Digital technologies in the accounting information system supporting decision-making processes*. "Scientific Papers of Silesian University of Technology – Organization and Management Series", Issue No. 169.
- Balicki J., Balicka H., Dryja P. (2021). *Big Data from Sensor Network via Internet of Things to Edge Deep Learning for Smart City*. [in:] K. Saeed, J. Dvorský (eds.), *Computer Information Systems and Industrial Management*. CISIM: "Lecture Notes in Computer Science", Vol. 12883. Cham: Springer, https://doi.org/10.1007/978-3-030-84340-3_29, pp. 357-368.
- Balicki J., Korłub W., Paluszak J. (2015). *Big data processing by volunteer computing supported by intelligent agents*. Proceedings of 6th International Conference, PREMI, Warsaw. Poland, June 30 - July 3. "Lecture Notes in Computer Science", Vol. 9124, p. 342.
- Balicki J., Korłub W., Tyszką M. (2016). *Harmony search to self-configuration of fault tolerant grids for big data*. "Advances in Intelligent Systems and Computing", Vol. 386, p. 411.
- Balicki J., Szymański J., Kępa M., Draszawka K., Korłub W. (2015). *Improving effectiveness of svm classifier for large scale data*. Proc. on 14th Int. Conf., ICAISC 2015, Zakopane, Poland, June 14-18. Part I "Lecture Notes in Computer Science", Vol. 9119, p. 677.
- Balicki J., Przybyłek P., Zadroga M., Zakidalski M. (2013). *Artificial neural networks and the support vector method in banking information systems*. "Contemporary Economy", Vol 4.
- Balicki J. (2009). *Multi-criterion decision making by artificial intelligence techniques*. Proceedings on the 8th Int. Con. on Artificial Intelligence. Knowledge Engineering and Data Bases, February, Cambridge, p. 322.

- Benbouzid B. (2019). *To predict and to manage. Predictive policing in the United States*. "Big Data & Society", January–June 2019, p. 7.
- Bosse T., Siddiqui G.F., Treur J. (2010). *Supporting Financial Decision Making by an Intelligent Agent Estimating Greed and Risk*. Proc. the IEEE/WIC/ACM Int. Conf. on Web Intelligence and Intelligent Agent Technology, Vol. 3, Aug. 31-Sept. 3, p. 367.
- Brown C. (2011). *Technical Analysis for the Trading Professional, Second Edition: Strategies and Techniques for Today's Turbulent Global Financial Markets*. New York: The McGrawHill Companies, p. 226.
- Ceny energii elektrycznej dla gospodarstw domowych na świecie. Pozyskano z: https://pl.globalpetrolprices.com/electricity_prices/, (27.03.2023).
- Ceny energii elektrycznej dla gospodarstw domowych w Polsce. Pozyskano z: <http://cena-pradu.pl/mapa.html>, (27.03.2023).
- Chen S.-H., Kuoand T.-W. Hoi K.-M. (2006). *Genetic Programming and Financial Trading: How Much about "What we Know"*. [in:] 4th NTU International Conference on Economics. Finance and Accounting, April, p. 2.
- Davis E. P., Karim D. (2008). *Comparing early warning systems for banking crises*. "Journal of Financial Stability", Vol. 4, No. 2, p. 89.
- Eurostat. (2021). Pozyskano z: <http://ec.europa.eu/eurostat/>, 12.03.2023.
- Gately E. (1999). *Neural networks. Financial forecasting and design of transaction system*. Warsaw: WIG-Press, s. 232.
- German Credit dataset. Pozyskano z: <http://archive.ics.uci.edu/ml/datasets/Statlog+%28German+Credit+Data%29>, 2.09.2022.
- Gierusz J., Koleśnik K. (2021). *Plan kont z komentarzem*. Gdańsk: ODDK.
- Hanschel E., Monnin P. (2005). *Measuring and forecasting stress in the banking sector: evidence from Switzerland*. "Investigating the Relationship between the Financial and Real Economy. BIS Papers", No. 22, pp. 435.
- Henley W. E., Hand D. J. (1996). *A k-nearest-neighbour classifier for assessing consumer credit risk*. "The Statistician", Vol. 45, Issue 1, p. 77.
- Jonek-Kowalska I., Kurdelski T. (2022). *The usage of renewable energy sources by countries in the Visegrád Group. Diagnosis and environmental effects*. "Scientific Papers of Silesian University of Technology – Organization and Management Series", Issue No. 161, <http://dx.doi.org/10.29119/1641-3466.2022.161.3>, pp. 37-51.
- Kumar K., Haider T. U. (2021). *Enhanced Prediction of Intra-day Stock Market Using Meta-heuristic Optimization on RNN-LSTM Network*. "New Gener. Comput", Vol. 39(1), pp. 231-272.
- Mylonakis J., Diacogiannis G. (2010). *Evaluating the likelihood of using linear discriminant analysis as a commercial bank card owners credit scoring model*. "International Business Research", Vol. 3, No. 2, p. 12.
- Nazari M., Alidadi M. (2013). *Measuring credit risk of bank customers using artificial neural net-work*. "Journal of Management Research", Vol. 5, No. 2, p. 322.
- Oet M., Eiben R., Bianco T., Gramlich D., Ong S., Wang J. (2011). *SAFE: an early warning system for systemic banking risk*. Proceedings of the 24th Australasian Finance and Banking Conference, SSRN.
- Potvin J.-Y., Soriano P., Vall M. (2004). *Generating trading rules on the stock markets with genetic programming*. "Computers & Operations Research", Vol. 31, p. 1033.
- Schwaerzel R. (2006). *Financial Time Series Prediction and Evaluation by Genetic Programming with Trigonometric Functions and High-Order Statistics*. Ph.D. Dissertation. The University of Texas at San Antonio. Advisor(s) Tom Bylander.

- Shouwei L., Mingliang W., Jianmin H. (2013). *Prediction of Banking Systemic Risk Based on Support Vector Machine*. "Mathematical Problems in Engineering", Vol. 12, April, p. 5.
- Staniec I. (2003). *Application of artificial neural networks and selected statistical methods to support credit decisions. Applications of statistical methods in scientific research II*. Cracow: StatSoft Poland, p. 20.
- Svangard N., Nordin P., Lloyd S., Wihlborg C. (2002). *Evolving short-term trading strategies using genetic programming*. Proc. of the Congress on Evolutionary Computation, Vol. 2, pp. 2006-2010.
- Yobas M.B., Crook J.N., Ross P. (2000). *Credit scoring using neural and evolutionary techniques*. "IMA Journal of Mathematics Applied in Business and Industry", Vol. 11, p. 112.
- Zan H. et al. (2004). *Credit rating analysis with support vector machines and neural networks: a market comparative study*. "Decision Support Systems", Vol. 37, p. 543.

INTERNET OF THINGS AND DEEP LEARNING MODELS FOR SUSTAINABLE DEVELOPMENT OF SMART CITIES

Abstract

The aim of the article is to characterize the directions of sustainable development of smart cities based on the use of the Internet of Things and deep learning models. According to the author, such a strategy creates a great opportunity to avoid the crisis in large cities resulting from the negative effects of the pandemic, urban density, climate change and environmental pollution. There is a gap in the literature on the subject, because there are no clear concepts on how to use selected technologies for the sustainable development of smart cities. For the above reasons, the article considers the strategies of using the Internet of Things and deep learning based on neural networks to increase the efficiency of the city's functioning and improve the quality of life of residents, while caring for the natural environment. An integrated city management system with the use of intelligent and ecological technologies has been characterized. The role and importance of the Internet of Things has been described in the context of managing critical city resources. On the other hand, issues related to deep learning models were presented in terms of the possibility of improving prediction and predicting results. Considerations on a special case of a deep learning architecture based on artificial neural networks (ANN) are presented. Recursive ANNs of the LSTM class were verified in terms of financial investments on the stock exchange. Finally, conclusions and planned future work were presented. The conclusions drawn on the basis of the conducted research clearly indicate that the IoT and deep learning models play an important role in the sustainable development of smart cities.

Keywords: Smart City, Green Economy, Internet of Things, Deep Learning

JEL classification: G17, M15, O33.

Honorata Balicka
Sopocka Akademia Nauk Stosowanych
81-855 Sopot, Rzemieślnicza 5
honorata.balicka@ssw-sopot.pl